

Long-Term Rainfall Estimation in Anzali City Using the Hybrid Wavelet-Adaptive Neuro-Fuzzy Inference System Model

IRAJ PASANDIDEH¹, MOHAMMAD ALI IZADBAKHS^{2*}, SAEID SHABANLOU²

1. Ph.D. Candidate, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran

2. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran

(Received: Jan. 23, 2019- Revised: March. 17, 2019- Accepted: March. 29, 2019)

ABSTRACT

Recently, the amount of rainfall underwent serious changes in different areas, particularly in arid and semi-arid regions. Therefore, estimation and pattern recognition of rainfall in a long term period can give sufficient information to hydrologists and water engineers. In this study, for the first time, long-term rainfall pattern in Anzali city for a 67 years period was simulated using a hybrid model so-called "Wavelet-Adaptive Neuro-Fuzzy Inference System" (WANFIS). Rainfalls of 37-, 20- and 10-years period were applied for training, testing and validation of the numerical model, respectively. Firstly, the optimized membership function of the ANFIS network was obtained using the analysis of the numerical results. In other words, the number of optimized membership function was computed to be equal to 8. Then, the various wavelet families were evaluated which the dmey mother wavelet was introduced as the most optimized wavelet family. Next, using the autocorrelation function (ACF), the partial autocorrelation function (PACF) and different lags, 15 WANFIS models were developed. According to the sensitivity analysis, the superior model and effective lags were identified. The superior model estimated the rainfall with high accuracy. For instance, for validation mode of the superior model, the correlation coefficient, scatter index and Nash-Sutcliffe efficiency coefficient were computed to be 0.962, 0.258 and 0.899, respectively.

Keywords: Rainfall, ANFIS, Wavelet, Sensitivity analysis, Simulation, Anzali city

برآورد بارش دراز مدت شهر انزلی توسط مدل ترکیبی سیستم‌های استنتاج فازی عصبی تطبیقی و تبدیل موجک

ایرج پسندیده^۱، محمد علی ایزدبخش^{۲*}، سعید شعبانلو^۲

۱- دانشجوی دکتری منابع آب، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

۲- گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

(تاریخ دریافت: ۱۳۹۷/۱۱/۳ - تاریخ بازنگری: ۱۳۹۷/۱۲/۲۶ - تاریخ تصویب: ۱۳۹۸/۱/۹)

چکیده

در سال‌های اخیر، میزان بارش در نواحی مختلف به خصوص در نواحی خشک و نیمه‌خشک، دچار تغییرات چشم‌گیری شده است. بنابراین، تخمین و الگوشناسی بارش در یک بازه دراز مدت می‌تواند به هیدرولوژیست‌ها و مهندسیین آب اطلاعات کافی ارائه کند. در این مطالعه برای اولین بار، بارندگی دراز مدت شهر انزلی در یک بازه زمانی ۶۷ ساله توسط مدل عددی موجک-سیستم استنباط فازی عصبی تطبیقی (WANFIS) شبیه‌سازی شد. برای آموزش، آزمون و صحت‌سنجی مدل‌های هوش مصنوعی به ترتیب از بارش‌های ۳۷، ۲۰ و ۱۰ ساله استفاده شد. در ابتدا، بهینه‌ترین تابع عضویت شبکه انفیس با استفاده از تجزیه و تحلیل نتایج مدل‌های مختلف به دست آمد. به عبارت دیگر، تعداد توابع عضویت بهینه برابر با هشت در نظر گرفته شد. سپس اعضای مختلف خانواده موجک مورد ارزیابی قرار گرفتند که *dmey* به‌عنوان بهینه‌ترین عضو این خانواده معرفی شد. در ادامه، با استفاده از تابع خودهمبستگی، خودهمبستگی نسبی و تأخیرهای مختلف، ۱۵ مدل WANFIS توسعه داده شدند. علاوه بر این، با استفاده از تحلیل حساسیت، مدل برتر و تأخیرهای مؤثر معرفی شدند. مدل برتر، مقادیر بارش را با دقت بالایی تخمین زد. به‌عنوان مثال، مقادیر ضریب همبستگی، شاخص پراکندگی و نش ساتکلیف برای مدل برتر در حالت صحت‌سنجی به ترتیب مساوی با ۰/۹۶۲، ۰/۲۵۸ و ۰/۸۹۹ محاسبه شدند.

واژه‌های کلیدی: بارش، انفیس، موجک، تحلیل حساسیت، شبیه‌سازی، شهر انزلی

مقدمه

بارندگی مهم‌ترین عامل تأمین منابع آب‌های زیرزمینی و سطحی در سطح کره زمین محسوب می‌شود. علاوه بر این، اهمیت تخمین و الگو شناسی بارش در مناطق مختلف جهان به خصوص نواحی خشک و نیمه‌خشک کره زمین بر کسی پوشیده نیست. در مقابل با توجه به اقلیم خشک و نیمه‌خشک فلات قاره ایران، مدل‌سازی الگوی بارندگی در این منطقه از اهمیت بسیار بالایی برخوردار است.

در سال‌های اخیر مدل‌های عددی فراوانی برای تخمین و الگو شناسی عوامل مختلف جوی از قبیل بارش در مناطق گوناگون جهان توسط محققین متعدد معرفی شده‌اند. به عنوان مثال؛ Lee *et al.* (1998). مقادیر بارش در یک نمونه آماری همگن را به وسیله شبکه عصبی مصنوعی پیش‌بینی نمودند. Wong *et al.* (1999). با استفاده از قواعد نو- فازی و شبکه عصبی مصنوعی مقادیر بارش در سوئیس را تخمین زدند. Toth *et al.* (2000). مقدار بارندگی در یک دوره زمانی ۵ ساله در کشور ایتالیا را به وسیله مدل‌های آرما (ARMA) و شبکه عصبی مصنوعی

پیش‌بینی کردند و با تجزیه و تحلیل نتایج مدل‌های مذکور بیان نمودند که شبکه عصبی مصنوعی دارای دقت بیشتری است. علاوه بر این، Wong *et al.* (2003). مقدار بارش در ۴۶۷ نقطه از کشور سوئیس را با استفاده از الگوریتم‌های مختلف شبکه عصبی مصنوعی و هوش مصنوعی تخمین زدند. آن‌ها داده‌های ۱۰۰ ایستگاه را برای آموزش مدل عددی و ۳۶۷ ایستگاه را برای آزمون این مدل مورد استفاده قرار دادند. حداکثر مقدار خطای نسبی برای مدل‌های آن‌ها تقریباً مساوی با ۰/۴۶ به دست آمد. Maqsood *et al.* (2004). با استفاده از روش‌های مختلف شبکه عصبی مصنوعی و مدل‌های رگرسیونی مبادرت به مدل‌سازی پارامترهای مختلف آب و هوایی نمودند و بیان کردند که مدل‌های شبکه عصبی مصنوعی مقادیر تابع هدف را با دقت بیشتری در مقایسه با مدل‌های رگرسیونی تخمین زدند. Riad *et al.* (2004). توسط شبکه عصبی مصنوعی مقادیر بارش و رواناب در یک حوضه واقع در کشور مراکش را تخمین زدند. آن‌ها با مقایسه نتایج مدل عددی خود با روابط رگرسیونی نشان دادند که مدل‌های هوش مصنوعی دارای دقت بیشتری هستند. همچنین Ramirez *et al.*

ژنتیک دارای عملکرد بهتری بود.

همچنین Khalili et al. (2008) مقادیر بارش در ایستگاه سینوپتیک شهر مشهد را با استفاده از شبکه عصبی مصنوعی مدل‌سازی کردند. آن‌ها از مجموع ۶۳۶ بارش ماهانه ۵۵۰ داده را برای آموزش و آزمون مدل عددی و باقیمانده آن‌ها را برای صحت سنجی مورد استفاده قرار دادند. (Khosravi and Shakiba (2010) مقادیر بارش در یک بازه زمانی ۴۳ ساله را توسط شبکه عصبی مصنوعی به منظور مدیریت سیل در ایران شهر مدل‌سازی کردند. آن‌ها ۸۰ درصد داده‌های خود را برای آموزش و مابقی را برای آزمون مدل عددی خود استفاده کردند. (Dehghani et al. (2016) مقادیر بارش- رواناب واقع در حوزه آبخیز کسلیان واقع در استان مازندران را توسط شبکه عصبی مصنوعی و مدل انفیس تخمین زدند. آن‌ها نشان دادند که شبکه انفیس مقادیر تابع هدف را با دقت بیشتری مدل‌سازی می‌کند.

از یک طرف، استفاده از مدل‌های هوش مصنوعی به دلیل دقت بالا و صرفه‌جویی در زمان و هزینه‌ها روزبه‌روز به شکل گسترده‌ای برای شبیه‌سازی پدیده‌های مختلف هیدرولوژیکی مورد استفاده قرار می‌گیرند. از طرف دیگر، تخمین و مدل‌سازی بارندگی در نواحی مختلف ایران به دلیل خشک‌سالی‌های پیاپی و تغییر الگوی بارندگی در فلات قاره ایران از اهمیت بسزایی برخوردار است. همچنین با بررسی مطالعات گذشتگان مشاهده می‌شود که استفاده از مدل‌های مختلف هوش مصنوعی به طور گسترده‌ای برای تخمین بارش و سایر پارامترهای هیدرولوژیکی مورد استفاده قرار می‌گیرند زیرا این مدل‌ها دارای دقت بالایی بوده و بسیار منعطف و مقرون به صرفه هستند. لازم به ذکر است که تخمین بارندگی بسیار مهم و ارزشمند است زیرا پیش‌بینی میزان بارندگی نقش مهمی در مدیریت سیلاب، پیش‌بینی ترسالی و خشک‌سالی دارد. همچنین، به دلیل افزایش جمعیت و صنعتی شدن در کشور ایران، مدیریت بارش و سایر منابع آب از اهمیت فوق‌العاده‌ای برخوردار است. بنابراین پیش‌بینی و الگوشناسی بارش در نواحی مختلف کشور بسیار مهم است که در این مطالعه، بارندگی ماهانه در شهر انزلی واقع در استان گیلان برای اولین بار با استفاده از مدل ترکیبی موجک-انفیس در یک بازه زمانی ۶۷ ساله از سال ۱۹۵۱ تا ۲۰۱۷ تخمین زده می‌شود که همین موضوع به‌عنوان مهم‌ترین نوآوری این مطالعه معرفی می‌شود.

مواد و روش‌ها

ناحیه مورد مطالعه

بندر انزلی در طول جغرافیایی ۴۹ درجه و ۲۸ دقیقه و عرض جغرافیایی ۳۷ درجه و ۲۸ دقیقه واقع شده است و ارتفاع آن از سطح دریا منفی ۲۶ متر می‌باشد. انزلی از شمال به دریای خزر از

(2005) مقادیر بارش روزانه در شهر سائوپائولو برزیل را توسط شبکه عصبی مصنوعی شبیه‌سازی کردند. آن‌ها نتایج مدل عصبی را با یک مدل رگرسیون خطی مقایسه کردند و بیان نمودند که مدل عصبی مقادیر تابع هدف را با دقت بیشتری پیش‌بینی می‌کند. (Aksoy and Dahamsheh (2009) توسط شبکه عصبی مصنوعی پیش‌خور پس انتشار خطا، تابع رادیال بیسیک و رگرسیون خطی به پیش‌بینی بارش یک ماهه در سه ایستگاه متفاوت را مدل‌سازی نمودند. آن‌ها نشان دادند که برای ایستگاه‌های با شرایط اقلیمی مرطوب مدل پیش‌خور پس انتشار خطا و برای ایستگاه‌هایی با شرایط اقلیمی خشک، مدل رگرسیونی مقادیر تابع هدف را با دقت بیشتری تخمین زدند. (Abhishek et al. (2012) احتمال بارندگی متوسط در ناحیه کارناتا واقع در هندوستان را به وسیله شبکه عصبی مصنوعی پیش‌بینی نمودند. آن‌ها برای فرمول‌بندی شبکه عصبی مصنوعی خود از سه شبکه لایه‌بندی شده با لایه‌های مخفی متفاوت استفاده کردند. (Akrami et al. (2014) با استفاده از شبکه انفیس، شبکه عصبی مصنوعی و موجک مدل‌های هوش مصنوعی ترکیبی برای تخمین بارندگی در حوضه رودخانه کلانگ واقع در کشور مالزی توسعه دادند. آن‌ها نتایج مدل‌های موجک- انفیس و موجک- شبکه عصبی مصنوعی را یکدیگر مقایسه کردند و نشان دادند که مدل موجک- انفیس مقادیر تابع هدف را با دقت قابل قبول‌تری تخمین می‌زند. در ادامه، (Hardwinarto and Aipassa (2015) شبکه عصبی مصنوعی را با شبکه عصبی مصنوعی پس‌خور را برای مدل‌سازی مقادیر بارش در کالیمانتان شرقی واقع در کشور اندونزی در یک بازه زمانی ۲۲ ساله مورد استفاده قرار دادند. آن‌ها نشان دادند که شبکه عصبی مصنوعی پس‌خور مقادیر بارندگی‌های مشاهداتی را با دقت بالاتری تخمین می‌زند. (Purnomo et al. (2017) دو مدل هوش مصنوعی برای پیش‌بینی مقادیر بارش ماهانه در نواحی مختلف در کشور اندونزی توسعه دادند. هر دو مدل دارای لایه ورودی، یک لایه پنهان و یک لایه خروجی بودند که مقادیر تابع هدف را با دقت مناسبی شبیه‌سازی کردند. علاوه بر این، (Danladi et al. (2018) بارش کوتاه مدت را بر روی دبی یک رودخانه در کشور نیجریه توسط مدل انفیس شبیه‌سازی کردند. آن‌ها تأثیر دما و رطوبت را بر روی پارامتر بارش مورد سنجش قرار دادند و بیان کردند مدل عددی مقادیر تابع هدف را با دقت خوبی تخمین زد. همچنین، (Cramer et al. (2019) توسط یک مدل تصادفی هوش مصنوعی تحت عنوان برنامه‌نویسی ژنتیک مقدار بارندگی در شهر شیکاگو آمریکا را شبیه‌سازی کردند. آن‌ها نتایج این مدل را با سایر الگوریتم‌های محاسباتی از قبیل رگرسیون بردار پشتیبان، درخت مدل M5 و دو مدل آماری مقایسه نمودند و نشان دادند که مدل تصادفی برنامه‌نویسی


مربعات خطا، بهره‌گیری می‌کند.

یک ساختار ANFIS را می‌توان با استفاده از یک سیستم استدلال فازی با دو متغیر ورودی (x, y) و یک متغیر خروجی (f) توصیف کرد. در سیستم ANFIS پایگاه قاعده سوگنو بکار برده می‌شود، در این ارتباط، یک پایگاه قاعده با دو قاعده به صورت زیر در نظر گرفته می‌شود:

قاعده اول $\text{if } x \text{ is } A_1 \text{ and } y \text{ is } B_1, \text{ then } f_1 = p_1x + q_1y + r_1$

قاعده دوم $\text{if } x \text{ is } A_2 \text{ and } y \text{ is } B_2, \text{ then } f_2 = p_2x + q_2y + r_2$

ساختار یک سیستم ANFIS با پنج لایه در شکل (۱) نمایش داده شده است.



شکل ۱. ساختار یک سیستم ANFIS

لایه اول (لایه ورودی): هر گره i در این لایه، یک گره سازگار (مربعی) با یک تابع عضویت است: (رابطه ۱)

$$O_{1,i} = \mu_{A_i}(x), \quad i = 1, 2 \quad \text{or} \quad O_{1,i} = \mu_{B_{i-2}}(x), \quad i = 3, 4$$

که A و B ترم‌های زبانی (مانند بالا و پایین) و $O_{1,i}$ نشان دهنده خروجی گره i ام در لایه اول است. در این لایه، درجه عضویت هر یک از متغیرها در مجموعه فازی متناظرشان به دست می‌آید. تابع عضویت نشان می‌دهد که هر نقطه در فضای ورودی با چه درجه عضویتی (عددی بین صفر و یک) به مجموعه فازی تعلق دارد و یا تا چه میزان ترم زبانی مربوط را ارضا می‌کند. تابع عضویت مورد استفاده در این مطالعه از نوع تابع عضویت گوسی است.

لایه دوم (لایه فازی‌ساز): گره‌های این لایه از نوع ثابت (دایره‌ای) می‌باشد و خروجی آن‌ها محصول سیگنال‌هایی است که از لایه اول به دست می‌آید:

$$O_{2,i} = w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y), \quad i = 1, 2 \quad (\text{رابطه ۲})$$

در این لایه وزن (یا قواعد تحریک) قواعد با استفاده از قواعد فازی به دست می‌آیند. در حقیقت، این لایه بخش مقدم (فرض) سیستم استدلال فازی را تشکیل می‌دهد.

لایه سوم (لایه نرمال‌سازی): هر گره در این لایه یک گره ثابت است. در این لایه وزن‌های به دست آمده از لایه قبل نرمال

جنوب به شهرستان صومعه‌سرا از شرق به شهرستان رشت و از غرب به شهرستان رضوان‌شهر متصل است. شهرستان انزلی در ناحیه‌ای کاملاً جلگه‌ای به صورت طولی و در ساحل دریای خزر واقع شده و دارای آب و هوای مرطوب ساحلی می‌باشد. میزان بارندگی شهرستان بسیار بالا بوده به طوری که بارش متوسط سالیانه تقریباً مساوی با ۱۸۹۲ میلی‌متر است. بیشترین بارندگی در ماه‌های شهریور و مهر با ۴۴۰/۹ میلی‌متر گزارش شده است. میزان رطوبت نسبی سالیانه به طور متوسط حدود ۷۱ تا ۹۷ درصد و درجه حرارت محیط بین ۵/۳ تا ۲۸ درجه سانتی‌گراد در نوسان می‌باشد. در این مطالعه، برای آموزش، آزمون و صحت‌سنجی نتایج مدل‌های عددی از مقادیر بارش دراز مدت ۶۷ ساله شهر انزلی استفاده می‌شود. به عبارت دیگر، ۳۷ سال مقادیر بارش جهت آموزش، ۲۰ سال برای آزمون و ۱۰ سال باقیمانده برای صحت‌سنجی مدل‌های هوش مصنوعی مورد استفاده قرار می‌گیرند. در جدول (۱) محدوده مقادیر بارش به همراه شاخص‌های آماری مختلف در سه حالت آموزش، آزمون و صحت‌سنجی مرتب شده است.

جدول ۱. محدوده مقادیر بارش به همراه شاخص‌های آماری مختلف در سه حالت آموزش، آزمون و صحت‌سنجی

وضعیت	حداکثر (mm)	حداقل (mm)	معیار متوسط (mm)	انحراف (mm)	اریانس (mm)
آموزش	۹۶۰	۰	۱۵۹/۲۱۶۹	۱۵۶/۶۸۵۸	۲۴۵۵۰/۴۳
آزمون	۷۴۲/۹	۰	۱۴۰/۶۲۳۳	۱۳۲/۵۳۸	۱۷۵۶۶/۳۲
صحت‌سنجی	۶۲۱/۴	۰	۱۵۱/۲۵۳۳	۱۴۳/۶۷۷۹	۲۰۶۴۳/۳۵

سیستم‌های استنتاج فازی عصبی تطبیقی (ANFIS)

شبکه ANFIS از ترکیب منطق فازی و شبکه‌های عصبی مصنوعی به وجود آمده است. یک شبکه تطبیقی، یک ساختار پیشرو چند لایه است که رفتار کلی خروجی آن به وسیله مقدار یک مجموعه از پارامترهای قابل اصلاح، تعیین می‌گردد (Jang, 1993). به عبارت دیگر، ساختار شبکه تطبیقی شامل یک مجموعه از گره‌های متصل به هم که به طور مستقیم به هم مرتبط شده‌اند و در آن هر گره یک واحد پردازش محسوب می‌شود. این سیستم‌ها مشکل اصلی در طراحی سیستم‌های فازی (به دست آوردن قواعد اگر- آنگاه در سیستم فازی) را به وسیله استفاده مؤثر از قابلیت یادگیری شبکه عصبی مصنوعی جهت تولید خودکار این قواعد و بهینه‌سازی پارامتر، حل کرده‌اند. شبکه ANFIS یکی از متداول‌ترین سیستم‌های عصبی فازی است که یک سیستم فازی سوگنو را در یک ساختار عصبی اجرا می‌کند. این سیستم برای فرایند آموزش از ترکیبی از روش‌های آموزش پس انتشار خطا و حداقل

این بسط برحسب توابع موجک نوشته می‌شود. موجک یک بازه محدود با میانگین صفر است، در صورتی که تبدیل فوریه یک تابع سینوسی است که از $-\infty$ تا $+\infty$ گسترده شده است. از طرف دیگر منحنی سینوسی فوریه یک منحنی نرم قابل پیش‌بینی است در حالی که موجک‌ها از قاعده خاصی پیروی نمی‌کنند. موج سینوسی از نظر تعداد و فراوانی دوره‌ها موضعی شده است ولی از نظر زمانی موضعی نیست در حالی که موجک هم از نظر فراوانی و هم از نظر زمانی موضعی شده است. بنابراین یک تبدیل که فرایند را به چند افق زمانی تجزیه کند آن را به شکلی در می‌آورد که دوره‌های تکرار، گروه‌ها و طبقات نوسان پذیر و ساختارهای جهش و ویژگی‌های عمومی و موضعی پویایی فرایند، متفاوت می‌شود. موجک‌ها توابع ریاضی هستند که داده‌ها را به اجزا فراوانی (فرکانس) تفکیک کرده و هر جزء را با نمایش متناسب به مقیاس آن جزء مطالعه می‌کنند.

موجک‌ها دارای جنسیت هستند. موجک پدر اغلب با ϕ و موجک مادر با نماد ψ نمایش داده می‌شود که به صورت زیر تعریف می‌شوند:

$$\phi_{j,k}(t) = S^{-\frac{j}{2}} \phi\left(\frac{t - S^j k}{S^j}\right) \quad (\text{رابطه ۷})$$

$$\psi_{j,k}(t) = S^{-\frac{j}{2}} \psi\left(\frac{t - S^j k}{S^j}\right) \quad (\text{رابطه ۸})$$

که ϕ موجک پدر و ψ موجک مادر هستند. همچنین، S پارامتر مقیاس، t زمان، k دامنه و j مقیاس مورد نظر می‌باشد. همان‌طور که ملاحظه می‌شود پارامتر مقیاس (S) نقش تحلیل موجک را از تحلیل فوریه متمایز می‌سازد. تغییر j دامنه دید را تغییر داده و می‌تواند تحلیل را از کلی به موضعی و برعکس تغییر دهد. موجک پدر انتگرالی برابر با یک و موجک مادر انتگرال برابر با صفر دارد. موجک پدر بخش هموار، روند (فرکانس پایین) سیگنال، و موجک مادر در بخش‌های جزئی (فرکانس بالا) را نشان می‌دهد. تبدیل موجک یک تابع مانند f می‌تواند به وسیله معادله زیر، نمایش داده شود:

$$W_{\psi} f(j, k) = 2^{-\frac{j}{2}} \int_{-\infty}^{+\infty} f(t) \psi\left(2^{-\frac{j}{2}} t - k\right) dt \quad (\text{رابطه ۹})$$

حال می‌توان رابطه‌ای بین سری‌های زمانی و نمایش موجک برقرار نمود. هر سری زمانی مانند $y(t)$ به صورت زیر نمایش داده می‌شود:

$$(\text{رابطه ۱۰})$$

$$y(t) = \sum_k S_{j,k} \phi_{j,k}(t) + \sum_k d_{j,k} \psi_{j,k}(t) + \sum_k d_{j-1,k} \psi_{j-1,k}(t) + \dots + \sum_k d_{1,k} \psi_{1,k}(t)$$

که در عبارت یاد شده $j=1,2,\dots,J$ است و J حداکثر مقیاس

می‌شوند و قوه تحریک قواعد به دست می‌آید:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (\text{رابطه ۳})$$

لایه چهارم (لایه غیرفازی سازی)

گره‌های این لایه از نوع گره‌های سازگار یا مربعی هستند. این لایه بخش نتیجه یک سیستم استدلال فازی را تشکیل می‌دهد و نتیجه هر یک از قواعد در این لایه به دست می‌آید.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad i = 1, 2 \quad (\text{رابطه ۴})$$

که p_i, q_i, r_i پارامترهای مربوط به بخش نتیجه هر یک از قواعد هستند و \bar{w}_i قوه تحریک نرمال شده است که از لایه پیشین به این لایه وارد می‌شود.

لایه پنجم (لایه ادغام): تنها گره این لایه، گره‌ای ثابت می‌باشد و نتایج به دست آمده از گره‌های لایه قبل در این گره، جمع‌بندی می‌شود و خروجی سیستم برای داده ورودی به دست می‌آید:

$$f = O_{5,i} = \sum \bar{w}_i f_i = \frac{\sum w_i f_i}{\sum w_i} \quad i = 1, 2 \quad (\text{رابطه ۵})$$

با توجه به ساختار ANFIS، خروجی سیستم، ترکیبی خطی از پارامترهای نتیجه $(p_1, q_1, r_1, p_2, q_2, r_2)$ است. به‌طور خلاصه:

(رابطه ۶)

$f = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2$
 $= \bar{w}_1 f_1 + \bar{w}_2 f_2 = (\bar{w}_1 x) p_1 + (\bar{w}_1 y) q_1 + (\bar{w}_1) r_1 + (\bar{w}_2 x) p_2 + (\bar{w}_2 y) q_2 + (\bar{w}_2) r_2$
 در گذر پیشروی الگوریتم آموزش ترکیبی، سیگنال‌های تابعی تا لایه پنجم به سمت جلو حرکت می‌کنند و در آنجا با پارامترهای قسمت نتیجه با استفاده از روش تخمین مربعات خطا، تعیین می‌شوند. در گذر پسرو، نرخ‌های خطا به سمت عقب انتشار یافته و پارامترهای فرض (مقدم) با استفاده از روش گرادیان کاهش، به دست می‌آیند. قابل ذکر است که روش استفاده شده جهت تولید سیستم استنتاج فازی از نوع fuzzy c-means clustering (FCM) می‌باشد.

تبدیل موجک^۱

تبدیل فوریه یک تابع $f(x)$ را به صورت بی‌نهایت تابع $\sin(ax)$ و $\cos(ax)$ ارائه می‌دهد. با وجود قابلیت خوب تبدیل فوریه در تحلیل سیگنال‌ها، این تبدیل دو عیب عمده دارد. اول آنکه توابع پایه فوریه (سینوس و کسینوس) برای نمایش سیگنال‌های پیچیده مناسب نبوده و دوم آنکه پارامتر زمان را حذف می‌کند. تبدیل موجک مشابه تبدیل فوریه با بسط توابع سروکار دارد ولی

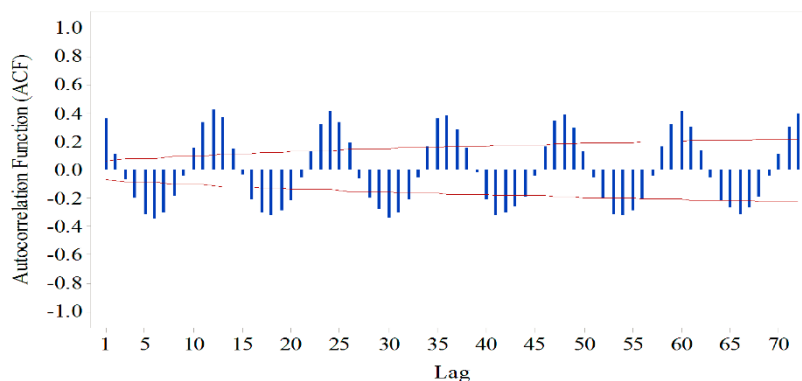
تأخیرها بیشترین اثر را دارند) در تمامی مدل‌ها، مدل‌های زیر پیشنهاد می‌شود.

- M1 $h(t) = f(h(t-1), h(t-12))$
- M2 $h(t) = f(h(t-1), h(t-2), h(t-12))$
- M3 $h(t) = f(h(t-1), h(t-4), h(t-12))$
- M4 $h(t) = f(h(t-1), h(t-5), h(t-12))$
- M5 $h(t) = f(h(t-1), h(t-6), h(t-12))$
- M6 $h(t) = f(h(t-1), h(t-2), h(t-4), h(t-12))$
- M7 $h(t) = f(h(t-1), h(t-2), h(t-5), h(t-12))$
- M8 $h(t) = f(h(t-1), h(t-2), h(t-6), h(t-12))$
- M9 $h(t) = f(h(t-1), h(t-4), h(t-5), h(t-12))$
- M10 $h(t) = f(h(t-1), h(t-4), h(t-6), h(t-12))$
- M11 $h(t) = f(h(t-1), h(t-5), h(t-6), h(t-12))$
- M12 $h(t) = f(h(t-1), h(t-2), h(t-4), h(t-5), h(t-12))$
- M13 $h(t) = f(h(t-1), h(t-2), h(t-4), h(t-6), h(t-12))$
- M14 $h(t) = f(h(t-1), h(t-4), h(t-5), h(t-6), h(t-12))$
- M15 $h(t) = f(h(t-1), h(t-2), h(t-4), h(t-5), h(t-6), h(t-12))$

مورد نظر است. در حقیقت در تبدیل موجک نیز مانند تبدیل فوریه، یک تابع یا سری زمانی به صورت مجموعه‌ای از جملات با توابع پایه موک بیان می‌شود با این تفاوت که توابع موجک به مانند سینوس و کسینوس نبوده و در برگیرنده پارامتر مقیاس هستند.

ترکیب ANFIS و تبدیل موجک (WANFIS)

به منظور مدل‌سازی ANFIS با تبدیل موجک، ابتدا داده‌ها باید به دسته‌های مختلف تقسیم می‌شوند. در ابتدا نیاز هست که ورودی مدل شناسایی شود. بنابراین در این مطالعه از تابع خود همبستگی^۱ (ACF) استفاده می‌شود. شکل ACF مربوط به داده‌های آموزشی در این مطالعه، در شکل (۲) ارائه شده است. با توجه به شکل مشاهده می‌شود که تأخیرهای ۱، ۲، ۴، و ۵ دارای تأثیر قابل توجهی در مدل‌سازی هستند. علاوه بر این، تأخیر زمانی ۱۲ که نشان دهنده دوره می‌باشد، نیز دارای تأثیر بسزایی است. بنابراین با در نظر گرفتن تأخیرهای ۱ و ۱۲ (که نسبت به سایر



شکل ۲. دیاگرام ACF برای داده‌های بخش آموزش مدل

که 1 برابر است با سطح تجزیه، n تعداد نمونه‌ها در حالت آموزش و int قسمت صحیح مقدار 1 است.

معیارهای بررسی دقت مدل‌های عددی

در مطالعه حاضر به منظور ارزیابی دقت مدل‌های عددی معرفی شده از شاخص‌های آماری ضریب همبستگی (R)، ضریب تغییرات (VAF)، خطای مربعات میانگین ریشه (RMSE)، شاخص پراکندگی (SI)، درصد خطای نسبی میانگین (MARE) و ضریب بهره‌وری نش ساتکلیف (ENS) به صورت زیر استفاده می‌گردد:

$$R = \frac{\sum_{i=1}^n (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (F_i - \bar{F})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (\text{رابطه ۱۲})$$

$$VAF = \left(1 - \frac{\text{var}(F_i - O_i)}{\text{var}(F_i)}\right) \times 100 \quad (\text{رابطه ۱۳})$$

پس از انتخاب داده‌های آموزشی و تعریف مدل‌های مختلف، دو گام اساسی دیگر پیش از انجام تحلیل وجود دارد، (۱) تعیین تابع موجک و (۲) سطح تجزیه. در استفاده از تبدیل موجک‌ها، تعیین نوع موجک و سطح بهینه تجزیه بسیار مهم است. یکی از نکات مهم و اساسی در انتخاب موجک مادر، طبیعت رخداد پدیده و نوع سری زمانی آن می‌باشد. بنابراین الگوهایی از توابع موجک مادر که بتواند به لحاظ شکل هندسی به خوبی بر منحنی سری زمانی منطبق شود، بهتر می‌تواند عمل نگاشت را انجام دهد و نتایج بهتری داشته باشند. توابع موجک مادر مورد استفاده در این مطالعه به شرح Db, haar, sym, coif, bior, rbio, dmey می‌باشد. علاوه بر آن، جهت تعیین سطح تجزیه از رابطه زیر Nourani et al., (2014) استفاده می‌شود:

$$l = \text{int}[\log(n)] \quad (\text{رابطه ۱۱})$$

دارد. به عبارت دیگر با انتخاب بهینه‌ترین تابع عضویت، مدل هوش مصنوعی از دقت قابل قبولی برخوردار است و در مقابل زمان محاسبات نیز معقول در نظر گرفته می‌شود. در شکل (۴) مقایسه شاخص‌های آماری مختلف برای توابع عضویت متفاوت شبکه انفیس در سه حالت آموزش، آزمون و صحت‌سنجی قابل مشاهده است. ابتدا، تعداد توابع عضویت مساوی با ۲ فرض شد و سپس با افزایش این پارامتر دقت مدل عددی مورد ارزیابی قرار گرفت. بر اساس نتایج مدل‌سازی، با افزایش توابع عضویت دقت مدل‌سازی به شکل قابل توجهی افزایش یافت. به‌عنوان مثال، مقدار شاخص پراکندگی در حالت آموزش برای توابع عضویت مساوی با ۲، ۳ و ۸ به ترتیب مساوی با ۰/۴۴۸، ۰/۳۸۱ و ۰/۳۴۰ محاسبه شدند. همچنین، مقادیر شاخص آماری $RMSE$ در وضعیت آزمون برای توابع عضویت ۶، ۷ و ۸ به ترتیب مساوی با ۵۰/۴۵۷، ۴۸/۲۱۲ و ۴۸/۲۲۱ می‌باشند. علاوه بر این، ضریب E_{NS} در وضعیت آزمون برای توابع عضویت مساوی با ۷، ۸ و ۹ برابر با ۰/۸۳۹، ۰/۸۵۹ و ۰/۸۵۸ تخمین زده شده‌اند.

همان‌گونه که مشاهده می‌شود، هنگامی که تابع عضویت مساوی با ۸ بود دقت مدل عددی در حد قابل قبولی بود بنابراین این تعداد تابع عضویت در ادامه مدل‌سازی مورد استفاده قرار می‌گیرد. در شکل (۵) نیز مقایسه مقادیر بارش مشاهداتی و شبیه‌سازی شده به همراه نمودار پراکندگی آن با تابع عضویت مساوی با ۸ در سه وضعیت آموزش، آزمون و صحت‌سنجی قابل مشاهده است. با توجه به نتایج مدل‌سازی بارش ماهانه توسط مدل انفیس، هنگامی که تابع عضویت برابر با ۸ در نظر گرفته شد، مقادیر شاخص‌های R ، MAE و $MAPE$ در وضعیت صحت‌سنجی به ترتیب برابر با ۰/۹۴۹، ۰/۱۲۴ و ۲/۰۹۵ به دست آمده‌اند.

بررسی خانواده‌های موجک

در این بخش به بررسی و تجزیه و تحلیل خانواده‌های مختلف تبدیل موجک پرداخته می‌شود. به طور کلی، تبدیل موجک دارای خانواده‌هایی با عنوان داوچییز^۱ (db)، هار^۲ (haar)، سایملتس^۳ (sym)، کویفلتس^۴ (coif)، بیورثوگونال^۵ (bior) و دی میر^۶ (dmey) است که هر کدام از این خانواده‌ها به ترتیب دارای ده، یک، هفت، پنج، سه و یک عضو هستند. بر اساس تجزیه و تحلیل کلیه اعضای خانواده‌های مختلف تبدیل موجک مشخص شد که تنها عضو خانواده دی میر دارای بیشترین همبستگی و کمترین خطا در مقایسه با مقادیر بارش مشاهداتی است. به‌عنوان مثال در وضعیت آزمون، مقادیر ضریب همبستگی و شاخص پراکندگی برای dmey به ترتیب مساوی با ۰/۹۵۲ و ۰/۲۸۹

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - O_i)^2} \quad \text{(رابطه ۱۴)}$$

$$SI = \frac{RMSE}{\bar{O}} \quad \text{(رابطه ۱۵)}$$

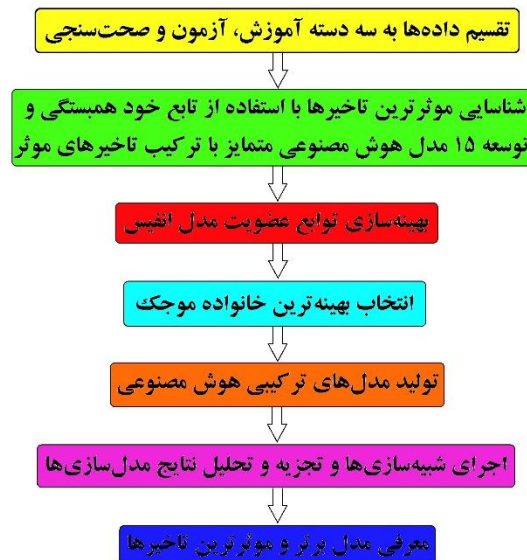
$$MARE = \frac{1}{n} \sum_{i=1}^n \left(\frac{|F_i - O_i|}{O_i} \right) \quad \text{(رابطه ۱۶)}$$

$$E_{NS} = 1 - \frac{\sum_{i=1}^n (O_i - F_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad \text{(رابطه ۱۷)}$$

در اینجا O_i مقادیر مشاهداتی، F_i مقادیر پیش‌بینی شده به وسیله مدل‌های عددی، \bar{O} میانگین مقادیر مشاهداتی و n برابر تعداد مقادیر مشاهداتی هستند.

نتایج و بحث

در ادامه به تجزیه و تحلیل نتایج مدل‌سازی‌ها پرداخته می‌شود. علاوه بر این فلوجارت این مطالعه در قالب شکل (۳) قابل مشاهده است.



شکل ۳- فلوجارت روند کار در مطالعه حاضر

انتخاب تابع عضویت بهینه شبکه انفیس

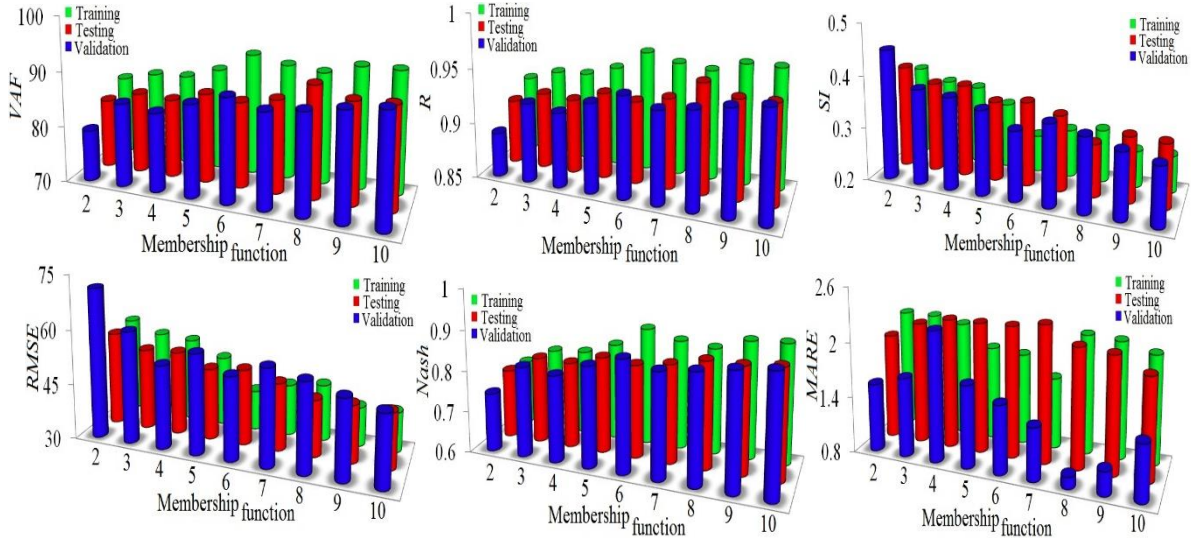
لازم به ذکر است که بیان شود در این مطالعه از مقادیر بارش ماهانه در یک بازه زمانی ۶۷ ساله از سال ۱۹۵۱ تا ۲۰۱۷ شهر آنزلی استفاده شده است. به بیان دیگر، ۳۷ سال بارش ماهانه برای آموزش مدل‌های هوش مصنوعی، ۲۰ سال برای آزمون و ۱۰ نیز برای صحت‌سنجی مدل‌های عددی استفاده می‌شود. در ابتدا به بررسی توابع عضویت شبکه انفیس پرداخته می‌شود. به طور کلی تعیین تابع عضویت بهینه نقش بسزایی در دقت و زمان محاسبات

4. Coiflets
5. Biorthogonal
6. DMeyer

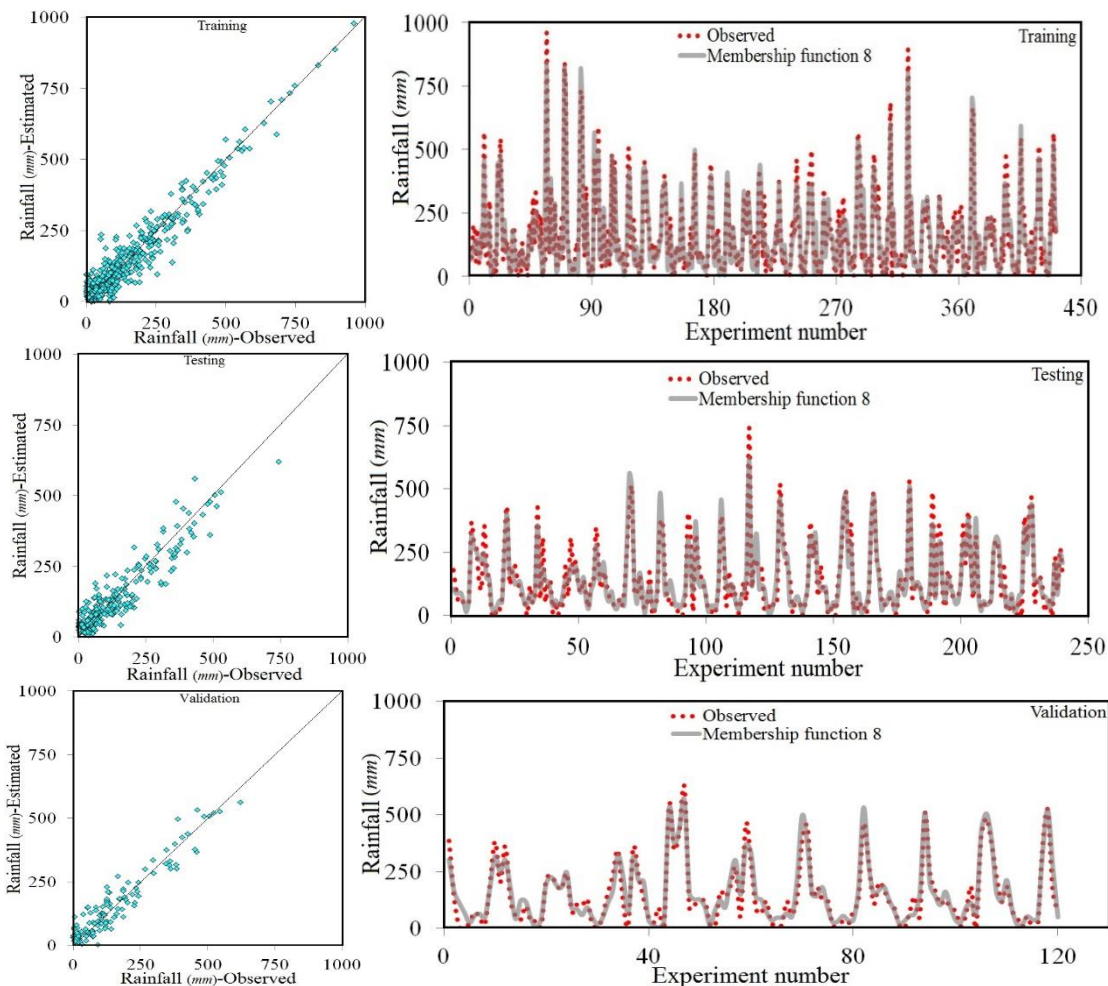
1. Daubechies
2. Haar
3. Symlets

شکل (۶) نتایج مقایسه مقادیر بارش مشاهداتی و شبیه‌سازی شده و نمودارهای پراکندگی برای d_{mey} در سه وضعیت آموزش، آزمون و صحت‌سنجی به تصویر کشیده شده است.

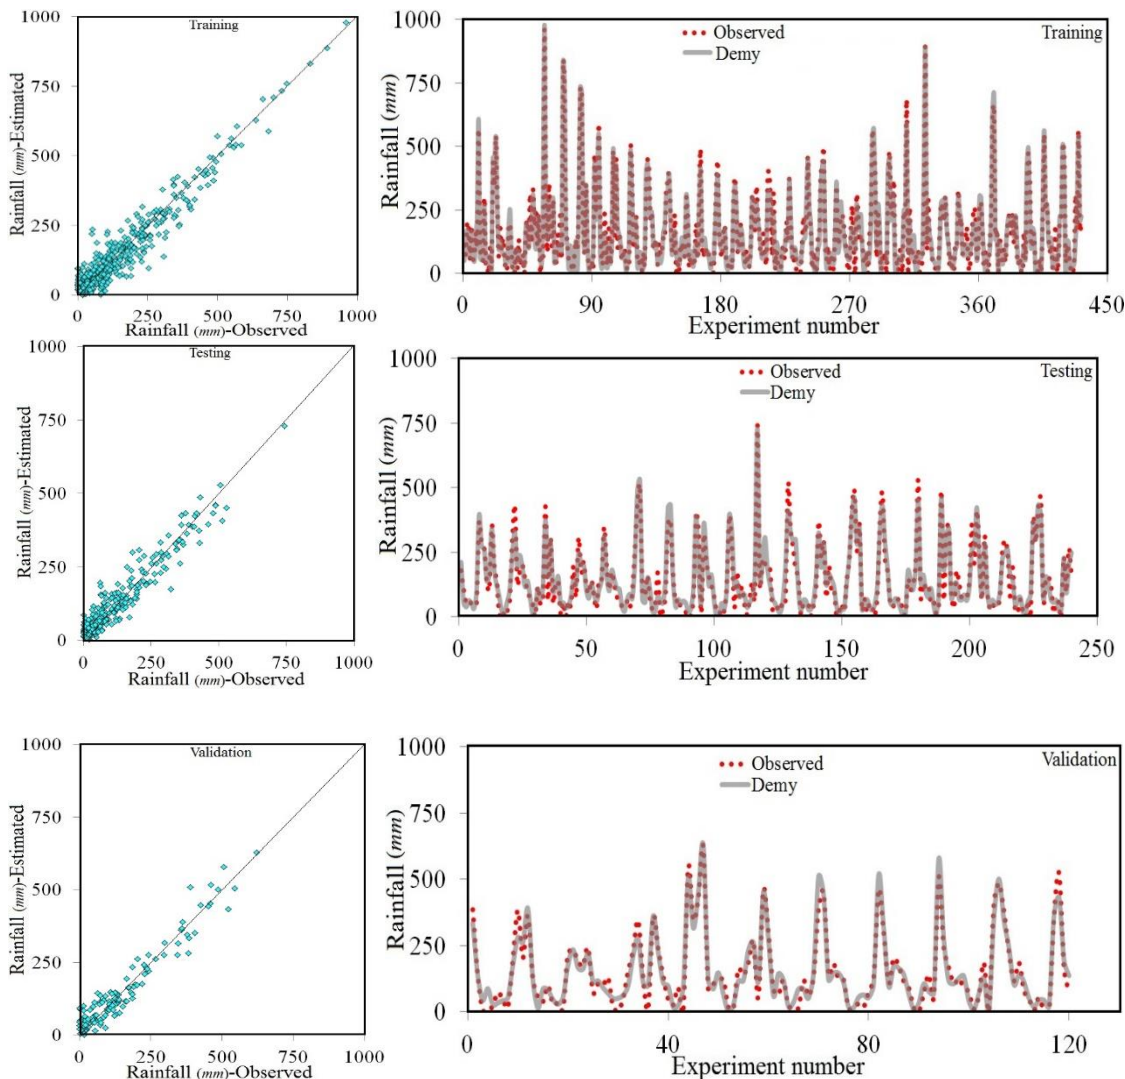
محاسبه شدند. این در حالی است که مقادیر VAF ، $RMSE$ و E_{NS} برای این عضو خانواده تبدیل موجک در شرایط صحت‌سنجی به ترتیب برابر با $۰/۸۹۹$ و $۳۸/۹۴۸$ و $۹۲/۶۰۷$ تخمین زده شدند. در



شکل ۴. مقایسه شاخص‌های مختلف برای توابع عضویت متفاوت شبکه انفیس در سه حالت آموزش، آزمون و صحت‌سنجی



شکل ۵. مقایسه نتایج بارش مشاهداتی و مدل‌سازی شده برای حالت‌های آموزش، آزمون و صحت‌سنجی تابع عضویت مساوی ۸



شکل ۶. مقایسه نتایج بارش مشاهداتی و مدل‌سازی شده برای حالت‌های آموزش، آزمون و صحت‌سنجی خانواده برتر موجک (demy)

و ۰/۴۵۲ محاسبه شده‌اند. لازم به یادآوری است که چهار مدل WANFIS 2 تا WANFIS 5 نیز با ترکیبی از ۳ پارامتر ورودی توسعه داده شده‌اند. همچنین مدل WANFIS 2 مقادیر تابع هدف توسط تأخیرهای یک، دو و دوازده پیش‌بینی می‌شوند. برای این مدل، شاخص SI در سه وضعیت آموزش، آزمون و صحت‌سنجی به ترتیب برابر با ۰/۲۷۸، ۰/۲۸۹ و ۰/۲۵۸ محاسبه شده‌اند. این در حالی است که شاخص‌های آماری $MARE$ و $RMSE$ برای این مدل در شرایط صحت‌سنجی به ترتیب مساوی با ۲/۰۸۸ و ۳۸/۹۴۹ تخمین زده شدند. لازم به ذکر است که مدل WANFIS 3 مقادیر بارش ماهانه را به وسیله تأخیرهای یک، چهار و دوازده مدل‌سازی می‌کند. برای این مدل در وضعیت آموزش، مقادیر R ، VAF و SI به ترتیب مساوی با ۰/۸۹۱، ۷۹/۲۰۵ و ۰/۴۴۸ محاسبه شده‌اند. همچنین، شاخص‌های آماری $MARE$ و ENS برای WANFIS 4 در شرایط صحت‌سنجی به ترتیب مساوی با ۲/۷۵۰ و ۰/۴۸۷ به دست آمده‌اند. لازم به ذکر است که مدل

تحلیل حساسیت مدل‌های WANFIS

همان‌گونه که بیان شد، با استفاده از تأخیرهای مختلف، پانزده مدل ترکیبی WANFIS تعریف شد که در این بخش به تجزیه و تحلیل نتایج مدل‌های پانزده‌گانه WANFIS پرداخته می‌شود. لازم به ذکر است که تبدیل موجک برای (۱) تجزیه و تحلیل فرکانس‌های داده‌های سری زمانی و (۲) افزایش دقت مدل ANFIS استفاده می‌شود. در جدول (۲) نتایج شاخص‌های آماری برای مدل‌های مختلف WANFIS در سه وضعیت آموزش، آزمون و صحت‌سنجی مرتب شده‌اند. در مطالعه حاضر یک مدل با دو پارامتر ورودی تعریف شده است (WANFIS 1). به‌عنوان مثال، مدل WANFIS 1 تابعی از تأخیرهای یک و دوازده است. برای این مدل مقادیر ضریب همبستگی و شاخص پراکندگی در شرایط آزمون به ترتیب مساوی ۰/۸۲۶ و ۰/۵۳۲ تخمین زده شده‌اند. علاوه بر این در وضعیت صحت‌سنجی، مقادیر VAF ، $RMSE$ و ENS برای مدل WANFIS 1 به ترتیب برابر با ۶۸/۵۶۹، ۸۰/۲۴۲ و

۴، ۵ و ۱۲ مقادیر بارش توسط مدل WANFIS 12 و تأخیرهای ۱، ۲، ۴، ۶ و ۱۲ توسط مدل WANFIS 13 شبیه‌سازی می‌شوند. مقدار ضریب همبستگی در شرایط آزمون برای مدل‌های WANFIS 12 و WANFIS 13 به ترتیب مساوی با ۰/۹۴۶ و ۰/۹۵۰ محاسبه شدند. این در حالی است که شاخص‌های آماری SI و ENS برای مدل WANFIS 14 در وضعیت صحت سنجی به ترتیب برابر با ۰/۵۶۰ و ۰/۴۸۷ به دست آمدند. این مدل مقدار تابع هدف را با استفاده از تأخیرهای شماره ۱، ۴، ۵، ۶ و ۱۲ تخمین می‌زند. در مطالعه حاضر تنها یک مدل مقادیر تابع هدف را با ترکیبی از ۶ پارامتر ورودی تخمین می‌زند (WANFIS 15). همچنین، مقدار ضریب همبستگی برای مدل WANFIS 15 در سه وضعیت آموزش، آزمون و صحت سنجی به ترتیب مساوی با ۰/۹۵۰، ۰/۹۵۰ و ۰/۹۴۷ محاسبه گردیده است. این مدل مقادیر بارش را با ترکیبی از تأخیرهای شماره ۱، ۲، ۴، ۵، ۶ و ۱۲ شبیه‌سازی می‌کند. بنابراین، بر اساس تحلیل حساسیت مدل‌های ۱۵ گانه WANFIS، مدل شماره ۲ (WANFIS 2) دارای بیشترین دقت و کمترین خطا در مدل‌سازی مقدار بارش ماهانه است.

مقایسه مدل برتر WANFIS با ANFIS

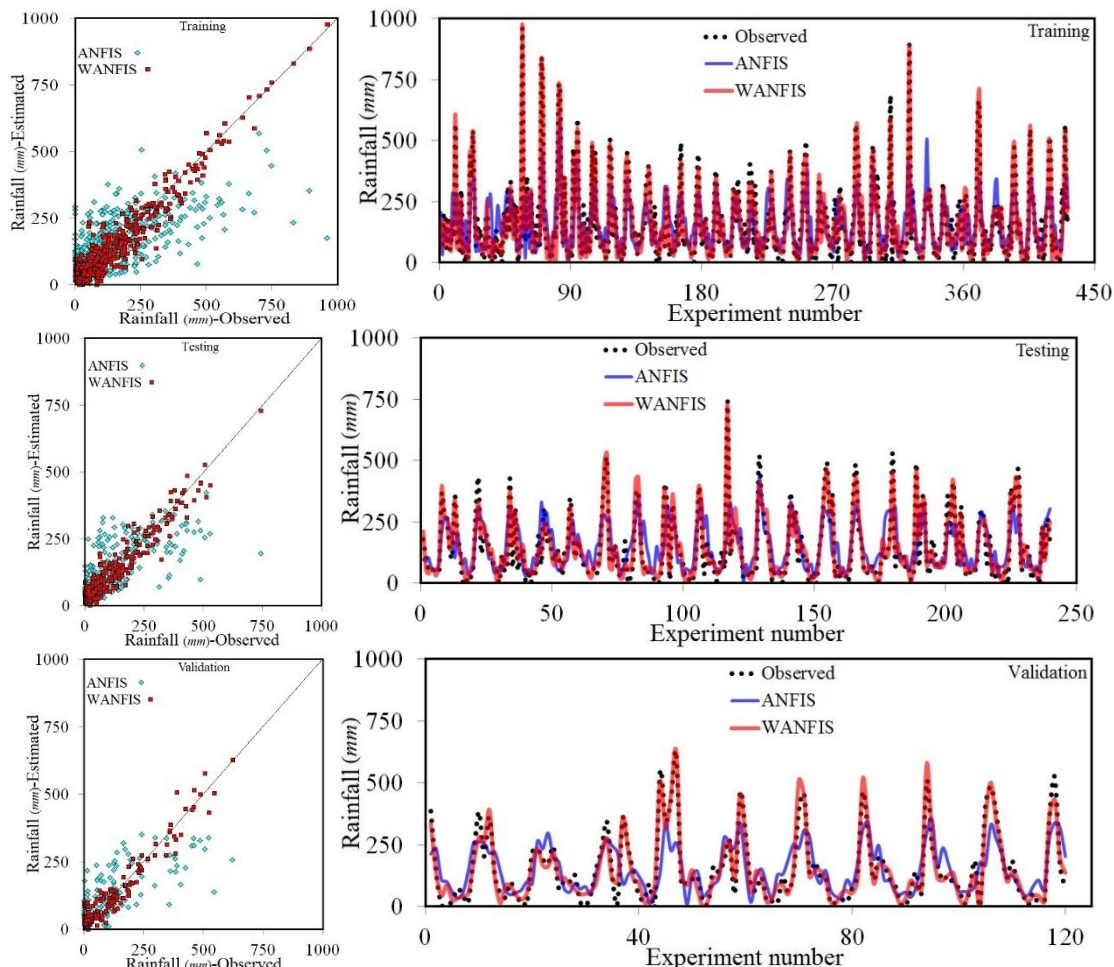
در ادامه مدل برتر WANFIS با ANFIS در سه وضعیت آموزش، آزمون و صحت سنجی مورد مقایسه قرار می‌گیرند. در شکل (۷) مقایسه بین مقادیر بارش شبیه‌سازی شده توسط مدل‌های برتر WANFIS و ANFIS با مقادیر مشاهداتی و نمودارهای پراکندگی آن‌ها به تصویر کشیده شده است. بر اساس نتایج مدل‌سازی، WANFIS در مقایسه با ANFIS در سه وضعیت آموزش، آزمون و صحت سنجی دارای دقت بیشتری است. به‌عنوان مثال، شاخص‌های آماری R ، SI و ENS در وضعیت آزمون برای مدل ANFIS به ترتیب برابر با ۰/۶۴۸، ۰/۷۱۹ و ۰/۲۵۸- و برای مدل WANFIS به ترتیب مساوی ۰/۹۵۲، ۰/۲۸۹ و ۰/۸۹۱ محاسبه شدند. علاوه بر این مقدار VAF در شرایط صحت سنجی برای مدل‌های ANFIS و WANFIS به ترتیب مساوی با ۴۱/۸۶۶ و ۹۲/۶۰۷ بودند. لازم به ذکر است که ترکیب تبدیل موجک و شبکه انفیسی باعث افزایش دقت مدل‌سازی شد به گونه‌ای که مقدار شاخص آماری $RMSE$ برای مدل WANFIS در مقایسه با مدل ANFIS حدوداً ۳۵ درصد کمتر محاسبه شد. بنابراین همان‌گونه که مشاهده شد، مدل هوش مصنوعی برتر (WANFIS 2) مقادیر بارش مشاهداتی را در یک بازه زمانی دراز مدت به خوبی شبیه‌سازی نمود. علاوه بر این، تأخیرهای شماره ۱، ۲ و ۱۲ نیز به‌عنوان مؤثرترین تأخیرها در این مطالعه شناسایی شد.

۴ مقادیر تابع هدف را بر حسب تأخیرهای یک، پنج و دوازده شبیه‌سازی می‌کند. برای ۴ WANFIS مقادیر شاخص‌های آماری VAF ، $RMSE$ و $MARE$ در حالت آزمون به ترتیب مساوی با ۰/۷۶/۹۰۸، ۶۳/۷۲۷ و ۲/۱۹۳ تخمین زده شده‌اند. مدل WANFIS 5 مقدار بارش ماهانه را بر حسب تأخیرهای شماره یک، شش و دوازده شبیه‌سازی می‌کند. برای مدل مذکور در شرایط صحت‌سنجی مقادیر ضریب همبستگی و شاخص پراکندگی به ترتیب برابر با ۰/۷۸۳ و ۰/۵۸۹ و در وضعیت آزمون به ترتیب مساوی با ۰/۸۱۸ و ۰/۵۴۳ محاسبه شده‌اند. سپس ۶ مدل WANFIS 6 تا WANFIS 11 نیز با ترکیبی از ۴ پارامتر ورودی مقادیر تابع هدف را تخمین زدند. این در حالی است که مدل WANFIS 6 مقدار تابع هدف را بر حسب تأخیرهای شماره یک، دو، چهار و دوازده پیش‌بینی می‌کند. برای مدل مذکور در حالت آموزش، مقادیر R ، VAF و SI را به ترتیب برابر با ۰/۹۴۶، ۶۱/۱۸۹ و ۰/۳۱۹ به دست آمده‌اند. تأخیرهای شماره یک، دو، پنج و دوازده برای شبیه‌سازی مقادیر بارش ماهانه توسط مدل WANFIS 7 مورد استفاده قرار می‌گیرند. به‌عنوان مثال، مقادیر شاخص پراکندگی برای وضعیت‌های آموزش، آزمون و صحت سنجی مدل WANFIS 7 به ترتیب مساوی ۰/۳۱۳، ۰/۳۰۶ و ۰/۲۹۷ محاسبه شده‌اند. این در حالی است که برای مدل WANFIS 8 مقادیر R ، $RMSE$ و ENS در شرایط صحت سنجی به ترتیب مساوی با ۰/۹۴۹، ۴۵/۳۱۵ و ۰/۸۵۶ تخمین زده شده‌اند. با توجه به ترکیب پارامترهای ورودی، مدل WANFIS 8 مقادیر تابع هدف را بر حسب یک، دو، شش و دوازده مدل‌سازی می‌کند. همچنین مقدار پارامتر ENS برای مدل‌های WANFIS 9 و WANFIS 10 در حالت آزمون به ترتیب برابر با ۰/۷۴۱ و ۰/۷۳۸ به دست آمدند. لازم به ذکر است که مقادیر $RMSE$ و $MARE$ برای مدل WANFIS 10 در وضعیت صحت سنجی به ترتیب مساوی ۸۵/۰۹۳ و ۲/۸۰۲ محاسبه شدند. مدل WANFIS 9 تابعی از تأخیرهای ۱، ۴، ۵ و ۹ و مدل WANFIS 10 تابعی از ۱، ۴، ۶ و ۱۲ هستند. این در حالی است که WANFIS 11 مقادیر تابع هدف را بر حسب تأخیرهای شماره ۱، ۵، ۶ و ۱۲ شبیه‌سازی می‌کند. برای این مدل شاخص‌های آماری VAF ، SI و ENS در شرایط آموزش به ترتیب برابر با ۰/۷۸/۲۴۳، ۰/۴۵۸ و ۰/۷۱۲ تخمین زده شدند.

لازم به ذکر است که مدل‌های WANFIS 12، WANFIS 13 و WANFIS 14 مقدار بارندگی را با ترکیبی از ۵ پارامتر ورودی شبیه‌سازی می‌کنند. با ترکیبی از تأخیرهای شماره ۱، ۲،

جدول ۲. نتایج شاخص‌های آماری برای مدل‌های مختلف WANFIS در سه وضعیت آموزش، آزمون و صحت‌سنجی

مدل	وضعیت	R	VAF	RMSE	SI	MARE	E_{NS}
WANFIS 1	Training	۰/۷۹۳	۶۲/۸۲۵	۹۴/۹۹۲	۰/۵۹۸	۲/۰۲۷	۰/۴۱۰
	Testing	۰/۸۲۶	۶۸/۲۰۰	۷۴/۷۷۳	۰/۵۳۲	۱/۸۳۱	۰/۵۲۴
	validation	۰/۸۲۸	۶۸/۵۶۹	۸۰/۲۴۲	۰/۵۳۱	۲/۷۱۴	۰/۴۵۲
WANFIS 2	Training	۰/۹۵۹	۹۱/۹۷۶	۴۴/۱۵۰	۰/۲۷۸	۱/۸۵۴	۰/۹۱۳
	Testing	۰/۹۵۲	۹۰/۶۶۷	۴۰/۶۰۰	۰/۲۸۹	۱/۵۰۵	۰/۸۹۱
	validation	۰/۹۶۲	۹۲/۶۰۷	۳۸/۹۴۹	۰/۲۵۸	۲/۰۸۸	۰/۸۹۹
WANFIS 3	Training	۰/۸۹۱	۷۹/۲۰۵	۷۱/۱۶۳	۰/۴۴۸	۲/۰۰۷	۰/۷۱۶
	Testing	۰/۸۹۳	۷۹/۷۷۶	۵۹/۸۰۱	۰/۴۲۵	۲/۱۳۰	۰/۷۴۷
	validation	۰/۸۱۴	۶۴/۷۶۵	۸۵/۰۷۸	۰/۵۶۲	۲/۷۵۰	۰/۴۸۷
WANFIS 4	Training	۰/۸۸۴	۷۸/۲۶۳	۷۲/۶۸۰	۰/۴۵۸	۲/۴۹۰	۰/۷۱۲
	Testing	۰/۸۷۷	۷۶/۹۰۸	۶۳/۷۲۷	۰/۴۵۳	۲/۱۹۳	۰/۷۰۳
	validation	۰/۸۳۴	۶۹/۲۶۵	۷۹/۴۰۱	۰/۵۲۵	۳/۰۲۹	۰/۵۳۸
WANFIS 5	Training	۰/۸۰۳	۶۴/۳۶۹	۹۲/۹۷۸	۰/۵۸۶	۲/۷۱۷	۰/۴۰۸
	Testing	۰/۸۱۸	۶۶/۷۲۴	۷۶/۴۰۸	۰/۵۴۳	۲/۱۳۲	۰/۵۴۴
	validation	۰/۷۸۳	۶۱/۱۸۹	۸۹/۱۳۸	۰/۵۸۹	۳/۱۲۰	۰/۳۸۰
WANFIS 6	Training	۰/۹۴۶	۸۹/۴۳۹	۵۰/۶۰۵	۰/۳۱۹	۱/۹۳۳	۰/۸۸۵
	Testing	۰/۹۴۷	۸۹/۴۵۶	۴۳/۰۰۱	۰/۳۰۶	۲/۰۷۴	۰/۸۶۸
	validation	۰/۹۴۸	۸۹/۸۳۰	۴۵/۶۳۳	۰/۳۰۲	۲/۸۶۸	۰/۸۵۲
WANFIS 7	Training	۰/۹۴۸	۸۹/۷۹۳	۴۹/۷۴۹	۰/۳۱۳	۲/۰۵۳	۰/۸۸۹
	Testing	۰/۹۴۷	۸۹/۴۷۰	۴۲/۹۶۶	۰/۳۰۶	۱/۹۱۸	۰/۸۷۱
	validation	۰/۹۵۰	۹۰/۱۲۷	۴۴/۹۸۳	۰/۲۹۷	۲/۵۴۵	۰/۸۵۹
WANFIS 8	Training	۰/۹۴۸	۸۹/۸۱۵	۴۹/۶۹۶	۰/۳۱۳	۱/۹۰۹	۰/۸۸۹
	Testing	۰/۹۵۱	۹۰/۱۹۱	۴۱/۴۳۴	۰/۲۹۵	۲/۰۸۱	۰/۸۷۹
	validation	۰/۹۴۹	۸۹/۹۷۵	۴۵/۳۱۵	۰/۳۰۰	۲/۸۳۵	۰/۸۵۶
WANFIS 9	Training	۰/۸۹۳	۷۹/۶۳۳	۷۰/۴۶۴	۰/۴۴۴	۲/۱۲۰	۰/۷۲۵
	Testing	۰/۸۹۲	۷۹/۵۶۱	۶۰/۲۱۳	۰/۴۲۸	۲/۱۲۲	۰/۷۴۱
	validation	۰/۸۱۶	۶۵/۱۶۵	۸۴/۵۸۵	۰/۵۵۹	۲/۷۰۶	۰/۴۸۹
WANFIS 10	Training	۰/۸۹۲	۷۹/۴۱۳	۷۰/۸۵۳	۰/۴۴۶	۲/۰۶۱	۰/۷۲۱
	Testing	۰/۸۹۰	۷۹/۲۲۴	۶۰/۶۶۴	۰/۴۳۱	۲/۱۵۳	۰/۷۳۸
	validation	۰/۸۱۳	۶۴/۸۰۰	۸۵/۰۹۳	۰/۵۶۳	۲/۸۰۲	۰/۴۸۵
WANFIS 11	Training	۰/۸۸۵	۷۸/۲۴۳	۷۲/۷۳۸	۰/۴۵۸	۲/۲۹۹	۰/۷۱۲
	Testing	۰/۸۷۷	۷۶/۸۵۴	۶۳/۸۲۷	۰/۴۵۴	۱/۸۷۷	۰/۶۹۹
	validation	۰/۸۳۰	۶۸/۵۳۲	۸۰/۴۲۷	۰/۵۳۲	۳/۲۴۶	۰/۵۲۱
WANFIS 12	Training	۰/۹۴۹	۹۰/۰۱۹	۴۹/۱۹۴	۰/۳۱۰	۱/۹۴۱	۰/۸۸۹
	Testing	۰/۹۴۶	۸۹/۳۶۸	۴۳/۱۸۰	۰/۳۰۷	۲/۰۵۲	۰/۸۷۲
	validation	۰/۹۴۸	۸۹/۸۸۳	۴۵/۵۶۷	۰/۳۰۱۷	۲/۸۶۲	۰/۸۵۷
WANFIS 13	Training	۰/۹۴۸	۸۹/۷۷۹	۴۹/۷۸۳	۰/۳۱۴	۱/۹۱۴	۰/۸۸۸
	Testing	۰/۹۵۰	۹۰/۱۳۲	۴۱/۶۱۷	۰/۲۹۶	۲/۰۴۳	۰/۸۸۰
	validation	۰/۹۴۶	۸۹/۴۴۱	۴۶/۴۹۵	۰/۳۰۷	۲/۸۳۵	۰/۸۵۰
WANFIS 14	Training	۰/۸۹۲	۷۹/۵۱۳	۷۰/۶۴۴	۰/۴۴۵	۲/۰۴۲	۰/۷۲۲
	Testing	۰/۸۹۰	۷۹/۲۳۳	۶۰/۶۴۹	۰/۴۳۱	۲/۰۸۴	۰/۷۳۷
	validation	۰/۸۱۶	۶۵/۱۲۸	۸۴/۶۳۵	۰/۵۶۰	۲/۷۲۲	۰/۴۸۷
WANFIS 15	Training	۰/۹۵۰	۹۰/۲۰۶	۴۸/۷۳۰	۰/۳۰۷	۲/۰۲۱	۰/۸۹۲
	Testing	۰/۹۵۰	۹۰/۱۷۸	۴۱/۵۱۶	۰/۲۹۵	۱/۹۸۵	۰/۸۸۲
	validation	۰/۹۴۷	۸۹/۵۹۵	۴۶/۱۵۴	۰/۳۰۵	۲/۸۳۵	۰/۸۵۴



شکل ۷. مقایسه نتایج بارش مشاهداتی و مدل سازی شده برای حالت های آموزش، آزمون و صحت سنجی مدل های برتر ANFIS و WANFIS

نتیجه گیری

بارش را بر حسب تأخیرهای شماره ۱، ۲ و ۱۲ با دقت قابل قبولی تخمین زد. به عنوان مثال، مقادیر R ، $RMSE$ و ENS برای وضعیت صحت سنجی مدل برتر به ترتیب مساوی با ۰/۹۶۲، ۰/۶۰۷/۹۲ و ۰/۸۹۹ محاسبه شدند. این مدل در مقایسه با مدل انفیس مقادیر بارش را در هر سه وضعیت آموزش، آزمون و صحت سنجی با دقت بیشتری تخمین زد. این مطالعه نشان داد که مدل های ترکیبی و فرا ابتکاری هوش مصنوعی توانایی خوبی در شبیه سازی پدیده بارندگی دارند. از طرف دیگر، با توجه به خشک سالی های دراز مدت و تغییر در سطح بارندگی در نواحی مختلف کشور ایران، استفاده از الگوریتم های متفاوت محاسبات نرم می تواند به عنوان یک ابزار کارآمد در زمینه بهره برداری و مدیریت منابع آب توسط مهندسیین و محققین استفاده شوند. همچنین پیشنهاد می شود از سایر الگوریتم های محاسبات نرم برای تخمین بارش در نقاط مختلف ایران استفاده گردد.

اخیراً، به دلیل تغییر اقلیم و گرمایش کره زمین، پیش بینی و تخمین بارش در نواحی مختلف جهان از اهمیت بسزایی برخوردار است. در این مطالعه، با استفاده از مدل انفیس و تبدیل موجک، یک مدل ترکیبی (WANFIS) برای تخمین بارش دراز مدت شهر انزلی در یک بازه زمانی ۶۷ ساله توسعه داده شد. ابتدا داده ها به سه دسته آموزش، آزمون و صحت سنجی تقسیم شدند. سپس با تجزیه و تحلیل نتایج مدل سازی، بهینه ترین تابع عضویت شبکه انفیس انتخاب شد. همچنین، نتایج اعضای مختلف خانواده های متفاوت موجک مورد ارزیابی قرار گرفت که عضو $dmey$ به عنوان دقیق ترین عضو معرفی گردید. در ادامه، پانزده مدل مختلف WANFIS با استفاده از تابع خود همبستگی و خود همبستگی نسبی و تأخیرهای مختلف تولید شد که با انجام تحلیل حساسیت برترین مدل هوش مصنوعی ترکیبی معرفی شد. این مدل مقادیر

REFERENCES

Abhishek, K., Kumar, A., Ranjan, R. and Kumar, S. (2012). A rainfall prediction model using artificial neural network. In Control and System Graduate

Research Colloquium (ICSGRC), IEEE (82-87). IEEE.

Akrami, S.A., Nourani, V. and Hakim, S.I.S. (2014)

- Development of nonlinear model based on wavelet-ANFIS for rainfall forecasting at Klang Gates Dam. *Water resources management*, 28(10), 2999-3018.
- Aksoy, H. and Dahamsheh, A. (2009). Artificial neural network models for forecasting monthly precipitation in Jordan. *Stochastic Environmental Research and Risk Assessment*, 23(7), 917-931.
- Cramer, S., Kampouridis, M., Freitas, A. A. and Alexandridis, A. (2019). Stochastic model genetic programming: Deriving pricing equations for rainfall weather derivatives. *Swarm and Evolutionary Computation*, 46, 184-200.
- Danladi, A., Stephen, M., Aliyu, B. M., Gaya, G. K., Silikwa, N. W. and Machael, Y. (2018). Assessing the influence of weather parameters on rainfall to forecast river discharge based on short-term. *Alexandria Engineering Journal*, 57(2), 1157-1162.
- Dehghani, N., Vafakhah, M. and Bahremand, E. (2016). Modeling of precipitation-runoff using artificial intelligence network and adaptive neuro-fuzzy inference network in Kasilian basin. *Journal of watershed management*, seventh year. 13, 128-137. (in Persian)
- Hardwinarto, S., and Aipassa, M. (2015). Rainfall monthly prediction based on artificial neural network: a case study in Tenggara Station, East Kalimantan-Indonesia. *Procedia Computer Science*, 59, 142-151.
- Jang, J.S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.
- Khalili, N., Khodashenas, S.R., Davari, K. and Mousavi Baygi, M. (2008). Prediction of daily precipitation using artificial intelligence networks, Case study: Mashhad synoptic station. *Watershed studies*, 89-99. (in Persian)
- Khosravi, M. and Shakiba, H. (2010). Prediction of precipitation using artificial intelligence networks in order to flood management: Case study: Iranshahr district. Fourth international congress of Islam world geographers. Zahedan, Iran. (in Persian)
- Lee, S., Cho, S. and Wong, P.M. (1998). Rainfall prediction using artificial neural networks. *Journal of geographic information and Decision Analysis*, 2(2), 233-242.
- Maqsood, I., Khan, M.R. and Abraham, A. (2004). An ensemble of neural networks for weather forecasting. *Neural Computing & Applications*, 13(2), 112-122.
- Nourani, V., Hosseini Baghanam, A., Adamowski, J. and Kisi, O. (2014). Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review. *Journal of Hydrology*, 514, 358-377.
- Purnomo, H.D., Hartomo, K.D. and Prasetyo, S.Y.J. (2017). Artificial neural network for monthly rainfall rate prediction. In *IOP Conference Series: Materials Science and Engineering*, 180: 1. 012057. IOP Publishing.
- Ramirez, M.C.V., de Campos Velho, H.F. and Ferreira, N.J. (2005). Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region. *Journal of hydrology*, 301(1-4), 146-162.
- Riad, S., Mania, J., Bouchaou, L. and Najjar, Y. (2004). Rainfall-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling*, 40(7-8), 839-846.
- Toth, E., Brath, A. and Montanari, A. (2000). Comparison of short-term rainfall prediction models for real-time flood forecasting. *Journal of hydrology*, 239(1-4), 132-147.
- Wong, K.W., Wong, P.M., Gedeon, T.D. and Fung, C.C. (2003). Rainfall prediction model using soft computing technique. *Soft Computing*, 7(6), 434-438.
- Wong, K.W., Wong, P.M., Gedeon, T.D. and Fung, C.C. (1999). Rainfall prediction using neural fuzzy technique. URL: [www. it. murdoch. edu. au/~wong/publications/SIC97](http://www.it.murdoch.edu.au/~wong/publications/SIC97). 213-221.